



张稳,李毅念,何瑞银,等.基于 RSSRP_YOLOv8 的离体稻穗结实率检测方法[J].南京农业大学学报,2026,49(4):930-944.

Zhang W, Li Y N, He R Y, et al. A RSSRP_YOLOv8-based method of detecting the rice seed-setting rate on detached rice panicle[J]. Journal of Nanjing Agricultural University, 2026, 49(4): 930-944.

基于 RSSRP_YOLOv8 的离体稻穗结实率检测方法

张稳,李毅念,何瑞银*,陆静,丁启朔

(南京农业大学工学院/江苏省智能化农业装备重点实验室,江苏 南京 211800)

摘要:[目的]针对水稻育种研究中离体稻穗样本结实率检测繁杂,脱粒检测易破坏稻穗结构等问题,本研究构建了一种基于改进 YOLOv8s 的稻穗结实率检测模型 RSSRP_YOLOv8(rice seed-setting rate on panicle using YOLOv8)。**[方法]**借鉴轻量级跨尺度融合结构(CNN-based cross-scale feature fusion,CCFF)重构原始模型颈部网络,减小模型体量及运算复杂性,提高检测效率;采用分组混洗卷积(grouped shuffle convolution,GSCov)取代模型骨干网络中的标准卷积和优化后 PAN-FPN 结构中的下采样标准卷积,促进稻穗籽粒特征信息提取与融合,提高识别准确率与效率;引入一种创新的动态上采样模块(dynamic sampling,Dysample)取代传统采样模块,提高模型多尺度特征融合和处理能力,促进稻穗籽粒特征细节重建和复杂场景中的特征恢复。**[结果]**RSSRP_YOLOv8 模型在测试集上的平均精度均值 mAP@0.5、精确度和召回率分别为 98.2%、95.6%、94.2%,相比于原始模型分别提高了 0.7%、0.6%、0.3%,模型浮点运算量和模型大小分别降低了 26.2%和 42.2%,模型检测帧率达到 64.9 f·s⁻¹。在 5 个品种水稻共计 1 100 张稻穗原始采集图上进行验证,模型对稻穗实粒、空秕粒和结实率的检测平均绝对误差(MAE)分别为 2.09 粒、1.77 粒和 0.92%,结实率平均检测精度达到 99%以上;平均绝对百分比误差(MAPE)分别为 2.27%、4.39%和 1.42%。**[结论]**该方法可实现离体稻穗结实率无损检测,为水稻育种研究中离体稻穗样本结实率检测提供技术支撑。

关键词:水稻;结实率;图像识别;YOLOv8;无损检测;表型

中图分类号:TP391.4;S126

文献标志码:A

文章编号:1000-2030(2026)04-0930-15

A RSSRP_YOLOv8-based method of detecting the rice seed-setting rate on detached rice panicle

ZHANG Wen, LI Yinian, HE Ruiyin*, LU Jing, DING Qishuo

(College of Engineering/Key Laboratory of Intelligent Agricultural Equipment of Jiangsu Province,
Nanjing Agricultural University, Nanjing 211800, China)

Abstract: [Objectives] Detecting the seed-setting rate of detached rice panicle samples is a tedious laboratory work in rice breeding. Pre-treatment with threshing causes damage to rice panicle, thus challenging the reliability of the assessed results. Therefore, this study aimed to develop an improved YOLOv8s-based rice seed-setting rate detection model, i.e. rice seed-setting rate on panicle using YOLOv8 (RSSRP_YOLOv8). [Methods] The model was optimized by incorporating the concept of a lightweight CNN-based cross-scale feature fusion (CCFF) to restructure the original model's neck network, leading to reduced model size and computational complexity while improving detection efficiency. The grouped shuffle convolution (GSCov) was applied to replace standard convolutions in both the model's backbone and the optimized PAN-FPN structure's down-sampling layers, which enhanced the extraction and integration of rice grain features and improved recognition accuracy and efficiency. An innovative dynamic up-sampling module (Dysample) was introduced to replace traditional up-sampling methods, resulting into enhanced multi-scale feature fusion and processing capability and thereby improving the reconstruction of rice grain feature details and recovering features in complex scenes. [Results] The RSSRP_YOLOv8 model achieved a mean average precision (mAP@0.5), precision and recall of 98.2%, 95.6% and 94.2%, respectively, using the test set, and related improvements were 0.7%, 0.6%, and 0.3% as compared to the original model. The model's floating-point operations and size were reduced by 26.2% and 42.2%, respectively, as compared to the original model. The detection frame rate reached 64.9 f·s⁻¹. Validation on 1 100 original rice panicle images from five rice varieties showed that the average absolute error (MAE) for detecting actual grains, empty grains, and seed setting rate were 2.09 grains, 1.77 grains, and 0.92%, respectively, with seed setting rate detection accuracy exceeding 99%. The mean absolute percentage error (MAPE) was 2.27%, 4.39% and 1.42%, respectively. [Conclusions] This method enables non-destructive detection of the seed-setting rate in detached rice panicles, providing technical support for seed-setting rate detection in detached rice panicle samples in rice breeding research.

Keywords: rice; seed-setting rate; image recognition; YOLOv8; non-destructive detection; phenotype

收稿日期:2025-02-14

基金项目:国家重点研发计划项目(2022YFD2300700)

作者简介:张稳,硕士研究生。*通信作者:何瑞银,教授,博导,研究方向为机器视觉与智能化农业装备, E-mail: ryhe@njau.edu.cn。

近年来,随着计算机视觉、人工智能和深度学习技术的快速发展,非接触性的智能化目标检测方法在果实检测领域得到广泛应用^[1],并根据处理流程分为双阶段和单阶段检测两类。在双阶段目标检测方法中,R-CNN(region convolutional neural networks)^[2]系列因较高的检测精度备受关注,但较大的模型体量和检测复杂性限制了其应用性能。相比于双阶段算法,以YOLO(you only look once)^[3]系列为代表的单阶段算法仅需单次前向传播即可完成目标检测,更适用于对实时性及推理速度要求较高的场景。随着YOLO系列的迭代更新,YOLOv8模型表现出优越性能,研究者们以YOLOv8为基础模型,提出了各类果实检测^[4-5]与成熟度评估^[6-7]、病虫害信息检测^[8-9]等模型,通过对原始模型结构或关键模块(如卷积层、注意力机制、损失函数等)的创新实现模型检测效率或精度提升,挖掘了YOLOv8模型的潜在应用价值,使其更贴近实际应用需求。

目前,基于机器视觉技术的水稻离体稻穗样本结实率检测方法主要分为脱粒检测和穗上检测2种。脱粒检测先通过人工或机械对稻穗脱粒,后采集籽粒图像并结合相关技术实现籽粒类别区分与结实率检测。Duan等^[10]提出了一种基于可见光和软X射线双模态成像相结合的稻穗脱粒籽粒自动识别方法,通过颖壳与内部谷粒投影面积比来计算籽粒填充率,总粒数和实粒数识别平均绝对百分比误差(MAPE)达到0.22%和0.80%;Liu等^[11]建立了一种基于水稻籽粒阴影特征的结实率检测方法,依据光照下不同籽粒的阴影特征区分籽粒类别,结实率预测结果与水漂法测量结果的相关系数达到0.952($P < 0.01$);Feng等^[12]提出了一种基于图像处理的籽粒物理特征测量方法,通过背光摄影结合聚类算法区分籽粒类别,总粒数和实粒数识别平均绝对百分比误差分别为0.24%和1.36%,并实现了籽粒长宽的测量;Zhou等^[13]利用热红外-可见光双成像系统来获取水稻籽粒的热红外图像和RGB图像,以图像配准方法、热红外去重影方法和多层嵌套粘连分割算法来计算结实率,精度达到97.66%。穗上检测省去了脱粒环节,直接实现籽粒类别区分与结实率检测。Kong等^[14]将X射线断层扫描(CT)系统表征的稻穗籽粒特征与Mask R-CNN算法相结合,基于三维层面实现稻穗籽粒特征提取与分类,检测准确率达到99%以上;Guo等^[15]提出了一种基于图像分割和深度学习技术的水稻稻穗结实率检测模型,该模型在测试集上的mAP值为83.98%,在10张稻穗图像上的结实率预测准确率达到99.43%。

水稻离体稻穗样本结实率检测中,脱粒检测过程烦琐,籽粒损耗严重,稻穗结构完整性受到破坏,现有穗上检测方法成本较高,模型性能及泛化性不足等。针对以上问题,本研究以1100株稻穗为研究对象,基于作物果实检测领域实时性与精确性得到广泛认可的YOLOv8s目标检测模型,构建了一种无需脱粒、精确度高、检测效率高的稻穗结实率检测模型——RSSRP_YOLOv8,以期水稻离体稻穗结实率检测提供一种新的有效途径,为育种研究提供技术支撑。

1 材料与方法

1.1 数据采集

1.1.1 样本采集 本研究分别于2023年10月25日、11月5日、11月15日在江苏省南京市多区域水稻试验基地(31°14'N—32°37'N,118°22'E—119°14'E)采集乳熟期、蜡熟期、完熟期3个时期的3个粳稻品种(‘南粳46’‘金粳818’‘宁粳8号’)稻穗900株,完熟期的2个籼稻品种(‘欣两优2172’‘九优粤禾丝苗’)稻穗200株,共计1100株,用于模型算法开发。

1.1.2 图像采集 稻穗采集完成后带至实验室拍摄其正视图像,图像采集平台如图1所示,该平台主要由机器视觉光源控制器(型号:AFT-ALP2406-02,北京维视数字图像有限公司)、双LED光源(型号:AFT-WL21244-22W,北京维视数字图像有限公司)、背景板、支架(型号:MV-BR601,北京维视数字图像有限公司)以及智能手机(型号:iPhone14,苹果公司)组成。图像采集过程中经光源控制器将光源强度调至3档,考虑到稻穗遮挡较为严重,因此人工将遮挡枝梗分开,共拍摄稻穗正视图像1100张,图片分辨率为3024×4023。

1.1.3 遮挡枝梗分离 遮挡是开发原位穗粒识别




图1 稻穗图像采集平台

Fig. 1 Rice panicle image acquisition platform

的主要问题, Sun 等^[16]提出了一种穗部形态指数(PMI), 用于量化籽粒遮挡程度, 并指出籽粒遮挡现象会影响模型检测精度。目前, 在基于图像识别等技术进行稻穗结实率精准检测时, 需进行枝梗分离操作以消除遮挡效应。本研究在图像采集过程中采用人工分离方法对稻穗的一次枝梗和部分二次枝梗进行分离。分离过程中, 首先将原始稻穗平置于背景板上, 通过适当指压主枝梗区域固定稻穗, 然后采用镊子对稻穗枝梗进行整形, 使稻穗一次枝梗和籽粒遮挡堆叠严重的二次枝梗依次展开。分离过程结合稻穗实际成熟情况与枝梗分布情况进行, 以保证枝梗在分离过程中不发生断裂, 分离过程如图 2 所示。自然状态下稻穗籽粒遮挡堆叠现象严重, 对稻穗一次枝梗进行分离可以显露大部分被完全遮挡的籽粒, 使得模型在训练过程中学习到更多籽粒特征, 同时显著降低模型漏检率, 提高检测精度; 对籽粒遮挡堆叠严重的二次枝梗进行分离, 有助于在模型训练中学习到的更丰富的籽粒细节特征, 提升籽粒识别能力, 增强检测准确性与可靠性。




图 2 稻穗枝梗分离过程示意图

Fig. 2 Rice panicle branch and rachis separation process diagram

1.2 数据集制作

1.2.1 数据标注 实粒与空秕粒随着稻穗生长表现出较为显著的颜色和形态学(纹理)差异, 如图 3 所示。本研究结合籽粒差异性并对照稻穗原始籽粒, 使用 LabelImg 工具, 选用最小外接矩形框对所采集 1 100 张稻穗图中的实粒和空秕粒进行对照标注。标注分为“Filled”和“Unfilled”两类, 代表实粒与空秕




图 3 稻穗籽粒样本

Fig. 3 Sample of rice panicle grains

粒,共标注标签类别 156 859 个,包含实粒标签 112 635 个,空秕粒标签 44 224 个。数据标注格式为 VOC 格式的 xml 文件,使用 Python 脚本将其转换为 YOLO 格式的 txt 文件。

1.2.2 数据增强 为增强数据多样性及鲁棒性,采用水平翻转、垂直翻转、随机对比度、添加椒盐噪声、平均池化、随机亮度调整 6 种方式进行数据增强,共得到 6 600 张稻穗图像。对扩充后的数据集按照 8:1:1 的比例进行划分,得到训练集 5 280 张、验证集 660 张、测试集 660 张图片用于模型开发,开发过程保证各数据集严格独立。

2 稻穗结实率检测模型——RSSRP_YOLOv8 的建立

本研究以 YOLOv8s 作为基础算法模型,但 YOLO 系列模型对小目标的检测表现不够理想^[17],而穗部籽粒分布较为密集,籽粒尺寸小,且育种研究样本量较大,复杂的原始模型难以满足检测需求。因此,本研究以水稻穗部籽粒精准区分和结实率快速检测为主体目标,对原始模型进行优化与改进,方法如下:1) 借鉴轻量级跨尺度融合结构 CCFF^[18] 重构原始模型颈部网络 (Neck) 的 PAN-FPN 结构,减少模型体量及运算复杂性,提高结实率检测效率;2) 采用分组混洗卷积模块 GSConv^[19] 取代模型骨干网络 (Backbone) 中的传统卷积和优化后 PAN-FPN 结构中的下采样标准卷积,实现模型计算性能、特征提取与融合能力的双重提升,提高模型对稻穗籽粒的特征提取能力。3) 引入一种创新的动态上采样器 Dysample^[20] 取代优化后 PAN-FPN 结构中的传统上采样模块 (upsample),提高模型的多尺度特征融合和处理能力,促进稻穗籽粒特征细节重建和复杂场景中的特征恢复。改进的稻穗结实率检测模型 RSSRP_YOLOv8 结构如图 4 所示。




图4 RSSRP_YOLOv8 模型结构

Fig. 4 RSSRP_YOLOv8 model structure

SPPF 表示空间金字塔池化模块;Conv 1×1 为 1×1 通道调整卷积;Dysample 表示动态上采样模块;Concat 表示张量拼接;Detect 为检测头;CBS 为卷积+标准化+激活函数;BatchNorm 表示标准化处理;Maxpool 表示最大池化;SiLU 为激活函数;Bbox.Loss 和 Cls.Loss 分别为边界框损失和分类损失。SPPF represents spatial pyramid pooling module;Conv 1×1 is the 1×1 channel adjustment convolution;Dysample represents dynamic sampling module;Concat represents tensor concatenation;Detect is the detection head;CBS is convolution + normalization + activation function;BatchNorm refers to normalization;Maxpool represents max pooling operation;SiLU is the activation function;Bbox.Loss and Cls.Loss are bounding box losses and classification losses, respectively.

2.1 轻量级跨尺度特征融合结构 CCFF (CNN-based cross-scale feature fusion)

为提高结实率检测效率,增强模型可扩展性和部署应用可能性,本研究借鉴轻量级跨尺度特征融合结构 CCFF 的思想重构了 YOLOv8s 原始网络模型中 Neck 部分的 PAN-FPN 结构。引入 1×1 卷积层对稻穗

籽粒的特征图进行特征压缩与变换,减少籽粒特征图通道数,实现稻穗籽粒特征信息的有效提取;通过结构重组降低模型体量和运算成本,提升检测效率。CCFF 跨尺度特征融合模块结构示意图如图 5 所示,该模块最早在 RT-DETR 模型的高效混合编码器(efficient hybrid encoder)中提出,编码器包含基于注意力的内部尺度特征交互模块 AIFI(attention-based intra-scale featureInteraction)和 CCFF。AIFI 模块通过一个单尺度 Transformer 编码器对来自 Backbone 的最高层次特征图 S5 进行处理,并利用自注意力机制增强特征图高层次语义信息的表达能力;CCFF 结构由上采样(upsample)、下采样(downsample)、 1×1 卷积、多级融合块(fusion block)等模块组成。多级融合块通过 2 个 1×1 卷积来调整通道数,使用 N 个 RepBlocks 进行特征融合,经元素集相加操作(element-wise add)实现不同路径的特征信息融合。CCFF 结构最终通过卷积操作高效融合了经 AIFI 处理的 F5 特征图以及来自 Backbone 的 S3 和 S4 特征图特征,显著提高模型特征表达能力和整体性能。




图 5 CCFF 模块结构图

Fig. 5 CCFF module structure diagram

本研究借鉴 CCFF 网络结构重构模型颈部网络,原因如下:1)通过引入 1×1 卷积层对稻穗籽粒特征图进行特征压缩与变换,压缩过程减少了籽粒特征图的通道数,降低了模型复杂度,变换过程通过线性组合不同通道提取出了更有用的稻穗籽粒特征信息。2)通过结构重组大幅降低了模型体量与运算成本,显著提高了稻穗检测速率,且重组结构即插即用的特性加强了模型可扩展性,提升了其应用性能。

2.2 分组混洗卷积模块 GSConv

原始网络模型使用大量标准卷积进行特征提取与融合,增加了模型复杂度。本研究在骨干网络和颈部网络中嵌入分组混洗卷积模块 GSConv 来优化模型,并对 Neck 部分的下采样标准卷积进行替换,降低了籽粒特征信息的冗余度,加速了模型特征提取过程。GSConv 模块主要由标准卷积 SC (standard convolution)、深度可分离卷积 DSC (depth-wise separable convolution)、Concat 模块和通道混洗模块(shuffle)等组成,如图 6 所示。假设输入特征图通道数为 C_1 ,期望特征图通道数为 C_2 ,通过对输入特征图进行标准卷积和深度可分离卷积操作,得到通道数均为 $C_2/2$ 的特征图和新特征图,将 2 个特征图进行拼接,得到通道数为 C_2 的拼接特征图,最终通过通道混洗操作得到通道数为 C_2 的期望特征图。GSConv 卷积模块采用深度可分离卷积和标准卷积相结合的形式,通过深度可分离卷积降低计算复杂度,通过标准卷积缓解由于深度可分离卷积的特征提取和融合能力弱而造成识别精度低的问题,并采用通道混洗策略在不同通道交换 Conv 模块和 DWConv 模块提取的特征信息。轻量级卷积模块 GSConv,标准卷积 SC、深度可分离卷积

DSC 的 $GFLOPs$ 计算公式分别如式(1)一式(3)所示。

$$GFLOPs = W \cdot H \cdot K_1 \cdot K_2 \cdot C_1 \cdot C_2 \quad (1)$$

$$GFLOPs_1 = W \cdot H \cdot K_1 \cdot K_2 \cdot C_2 \quad (2)$$

$$GFLOPs_2 = W \cdot H \cdot K_1 \cdot K_2 \cdot \frac{C_2}{2} (C_1 + 1) \quad (3)$$

式中: $GFLOPs$ 、 $GFLOPs_1$ 、 $GFLOPs_2$ 分别为不同卷积模块浮点计算量; W 、 H 分别表示特征图宽度和高度; $K_1 \cdot K_2$ 表示卷积核大小; C_1 表示输入通道数; C_2 表示输出特征图通道数。




图6 GSConv 模块结构图

Fig. 6 GSConv module structure diagram

本研究将卷积模块 GSConv 引入网络模型,原因如下:1) GSConv 采用标准卷积和深度可分离卷积并行的方式减少了稻穗籽粒的特征冗余,捕捉到稻穗籽粒的多尺度特征,并通过通道混洗模块加强特征信息的提取,增强了稻穗籽粒的识别精度。2)信号处理层面,GSConv 通过空间注意力加强穗粒纹理特征权重分配的同时,利用通道压缩抑制了背景干扰信号,通过建立动态特征选择机制,提高了复杂背景下稻穗籽粒的识别能力。3)通过 GSConv 替代传统下采样标准卷积,可加速籽粒特征图的提取与处理,其分层特征融合策略优化了模型的计算流程,进而提高了在穗籽粒的检测速率。

2.3 动态上采样模块 Dysample

在目标检测领域,特征上采样是密集预测模型中逐步恢复特征分辨率的关键因素。常用的上采样方法包含传统上采样方法(最近邻插值、双线性插值等)和基于内核的动态上采样模块(CARAFE 等)。YOLOv8 采用最近邻插值上采样方法将输入特征图的尺寸进行匹配,以实现不同尺度的特征融合,但该方法依靠像素点空间位置信息决定上采样核,容易丢失重要特征信息。

本研究引入一种创新的轻量又有效的动态上采样模块 Dysample,该模块基于点采样角度制定上采样,如图7所示。首先给定一个尺寸大小为 $C \times H \times W$ 的特征映射 X 和经动态采样点生成器生成的大小为 $2g \times sH \times sW$ 的点采样集 S ,然后经 `grid_sample` 函数使用点采样集中的位置将特征映射 X 重新采样为大小为 $C \times sH \times sW$ 的 X' 。该过程如式(4)所示:

$$X' = \text{grid_sample}(X, S) \quad (4)$$

式中: X 、 S 、 X' 分别为原始特征映射 X 、点采样集 S 、采样后特征 X' 。

点采样集 S 经动态采样点生成器生成。首先,给定上采样比例因子 σ 特征映射 X , X 经输入和输出通道分别为 C 和 $2gs^2$ 的线性层生成大小为 $2gs^2 \times sH \times sW$ 的偏移量 O ,再通过像素重组(pixel shuffle)将其大小重塑为 $2g \times sH \times sW$,最终点采样集 S 为偏移量 O 与原始采样网格 G 之和,具体表达式如式(5)和(6)所示:

$$O=\text{linear}(X)$$

(5)

$$S=O+G$$

(6)

式中: O 、 G 分别表示生成偏移量、原始采样网格。




图 7 Dysample 模块结构图

Fig. 7 Dynamic module structure diagram

H 、 W 分别为输入特征图的高和宽; sH 、 sW 为输出特征图的高和宽; C 为对应特征图的通道数; X 为原始特征映射; X' 为采样后特征; σ 为动态上采样比例因子; S 为点采样集。 H 、 W is the height and width of the input feature map; sH 、 sW is the height and width of the output feature map; C indicates the number of channels in the corresponding feature map; X is the original feature representation; X' is the sampled feature; σ is the dynamic upsampling scale factor; S is the point sampling set.

本研究采用动态上采样模块 Dysample,原因如下:1)原始模型中的最近邻插值上采样方法缺乏细节特征重建能力,易导致信息丢失,而稻穗图像中的实粒和空秕粒主要以纹理、颜色等细节特征区分为主。Dysample 动态上采样模块的引入有效提升了籽粒特征的细节信息重建,保证了稻穗籽粒识别精度;2)Upsample 上采样模块依靠像素点的空间位置信息决定上采样核,在处理籽粒分布密集且复杂的稻穗图像信息时表现不佳。基于点重采样方法进行上采样的动态上采样模块 Dysample 能更有效地适应这种复杂性,促进模型精度提升。

3 结果与分析

3.1 模型训练与评估

3.1.1 试验平台及训练参数 本试验在 Ubuntu 20.04.6 LTS (Linux) 操作系统上进行,CPU 为 Intel(R) Xeon(R) CPU E5-2686 v4,GPU 为 Nvidia GeForce RTX 3090,显存 24 GB。采用 PyTorch2.2.1 深度学习框架基于 Python3.11.7 进行程序编写,使用运算架构 Cuda12.1 加速 GPU。采用 SGD (stochastic gradient descent) 优化器加速模型训练,降低模型陷入局部最优的可能性。训练参数设置如表 1 所示。

表 1 训练参数

Table 1 Training parameters

参数 Parameters	数值 Values	参数 Parameters	数值 Values	参数 Parameters	数值 Values	参数 Parameters	数值 Values
Epochs	300	Img_size	640	Momentum	0.937	Patience	100
Batch	8	Max_det	300	Weight_decay	0.000 5		
Workers	12	Lr0	0.01	Warmup_momentum	0.8		

3.1.2 评价指标 采用准确率 P (precision,%)、召回率 R (recall,%)、平均精度均值 mAP (mean average precision,%)来衡量模型准确度,分别如式 (7)—式 (9) 所示;通过浮点运算量 FLOPs (floating point operations,G)、参数量 (parameters,MB)、模型大小 (model size,MB)、帧速率 FPS (frames per second, $f \cdot s^{-1}$) 作为模型性能评价指标。

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (7)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (8)$$

$$mAP = \frac{\sum_{i=1}^n \int_0^1 P(R) dR}{n} \times 100\% \quad (9)$$

式中: T_p 为图中正确检测的样本数; F_p 为被误测的样本数; F_N 为未被正确检测的样本数; n 为类别数量, 本研究的籽粒类别为实粒和空秕粒 2 种, 故 $n=2$ 。

3.1.3 改进模块独立贡献度量化指标 基于 Shapley 值^[21] 分析法量化分析了各改进模块的独立贡献度。在机器学习中, Shapley 值分析法主要用于量化各改进模块对模型整体性能指标的对应贡献, Shapley 值计算如式(10)所示。

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (n - |S| - 1)!}{n!} [v(S \cup \{i\}) - v(S)] \quad (10)$$

式中: ϕ_i 表示模块 i 的 Shapley 值; i 代表模型所加模块, 包括 CCFF、GSCConv、Dysample 模块; N 表示所有模块的集合; S 表示不包含模块 i 的子集; n 表示模块数量, 本研究中 $n=3$; $|S|$ 表示子集 S 中的模块数量; $v(S \cup \{i\})$ 表示子集 S 加入模块 i 后的性能指标值; $v(S)$ 表示子集 S 的性能指标值。

在保证精度前提下, 离体稻穗结实率检测需满足检测实时性需求, 因此在独立贡献度量化分析中选择 mAP@0.5 和 FPS 作为性能指标, 分配权重均为 0.5, 加权后的综合 Shapley 值计算如式(11)所示。

$$\phi_i^{\text{综合}} = 0.45 \times \frac{\phi_i^{\text{mAP@0.5}}}{\text{MaxFPS}} + 0.55 \times \frac{\phi_i^{\text{FPS}}}{\text{MaxmAP}} \quad (11)$$

式中: $\phi_i^{\text{综合}}$ 表示加权后的综合 Shapley 值; MaxFPS 、 MaxmAP 分别表示消融试验所有组合中的最大帧率增益和最大 mAP@0.5 增益, 依据消融试验结果, 取值分别为 11、0.3。

3.1.4 水稻结实率检测性能评估指标 水稻结实率 (rice seed setting rate, RSSR)、总粒数 (total grains number, TGN)、实粒数 (filled grains number, FGN) 及空秕粒数 (unfilled grains number, UGN) 之间关系表达式如式(12)所示。

$$\text{RSSR} = \frac{\text{FGN}}{\text{TGN}} = \frac{\text{FGN}}{\text{FGN} + \text{UGN}} \times 100\% \quad (12)$$

为进一步衡量模型应用性能, 利用模型对 1 100 张稻穗原始图像识别得到的参数 (实粒数、空秕粒数、总粒数、结实率) 预测值与实际值建立相关性模型。并采用决定系数 (coefficient of determination, R^2)、均方根误差 (root-mean-square error, RMSE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、平均绝对误差 (mean absolute error, MAE) 进行评估, 表达式分别如式(13)~式(16)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2} \quad (13)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (15)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

式中: n 为样本数量; y_i 、 $\hat{y}_i$ 、 $\bar{y}_i$ 分别表示每张稻穗图像中各参数对应的原始值、预测值、原始值算术平均数。

3.2 模型试验结果与分析

3.2.1 主流模型检测性能对比 为验证 RSSRP_YOLOv8 模型相比热门目标检测模型的优越性, 对 660 张稻穗测试数据集进行测试, 以精确度、召回率、mAP@0.5、mAP@0.5~0.95、浮点计算数、参数量、模型大小

作为评价指标,并选取同一测试集与主流目标检测模型 Faster_RCNN、rtddetr-l、YOLOv5s、YOLOv7、YOLOv8n、YOLOv8s、YOLOv10s^[22]进行对比试验,试验结果如表2所示。Faster R-CNN 模型精度较低,分析原因可能是双阶段目标检测算法对小目标检测(如稻穗籽粒)的性能局限性。相比于原始 YOLOv8s 模型,改进模型 RSSRP_YOLOv8 的浮点运算量、参数量和模型大小分别降低了 26.22%、42.86%、42.22%,精确率、召回率、mAP@0.5 分别提高了 0.7%、0.6%、0.3%,尽管 mAP@0.5~0.95 降低 0.5%,但以较低的精度丢失为代价显著降低了模型体量和计算复杂性,提高了模型部署的可行性。相比于其他主流模型,改进模型 RSSRP_YOLOv8 对稻穗籽粒识别的精确度比 Faster_RCNN、rtddetr-l、YOLOv5s、YOLOv7、YOLOv8n、YOLOv10s 分别提高 39.7%、17.2%、3.0%、7.7%、6.5%、1.3%;召回率分别提高 42.5%、16.7%、4.8%、9.2%、5.9%、2.1%;mAP@0.5 分别提高 34.8%、19.1%、2.4%、6.1%、4.1%、0.7%;mAP@0.5~0.95 分别提高 32.0%、37.9%、3.5%、12.4%、7.1%、1.3%;改进后的模型大小相比于双阶段目标检测算法 Faster_RCNN、rtddetr-l 分别降低了 309.6 和 51.7 MB,相比于单阶段算法 YOLOv5s、YOLOv7、YOLOv10s 分别降低了 1.4、60.1、3.2 MB,可知改进模型在任务精度要求和低算力部署方面取得良好平衡,更适用于稻穗籽粒识别和穗部结实率检测。

表2 不同模型对比试验结果

Table 2 Comparative experiments results of different models

模型 Models	精确度/% Precision	召回率/% Recall	mAP@0.5/%	mAP@0.5~0.95/%	浮点运算量/GB FLOPs	参数量/MB Parameters	模型大小/MB Model size
Faster_RCNN	55.9	51.7	63.4	41.4	240.1	42.1	322.6
rtddetr-l	78.4	77.5	79.1	35.5	107.4	32.1	64.7
YOLOv5s	92.6	89.4	95.8	69.9	16.0	7.0	14.4
YOLOv7	87.9	85.0	92.1	61.0	105.1	37.2	73.1
YOLOv8n	89.1	88.3	94.1	66.3	8.9	3.2	6.3
YOLOv8s	94.9	93.6	97.9	73.9	28.6	11.2	22.5
YOLOv10s	94.3	92.1	97.5	72.1	24.8	8.1	16.2
RSSRP_YOLOv8	95.6	94.2	98.2	73.4	21.1	6.4	13.0

为更直观地比较模型检测效果,将改进模型 RSSRP_YOLOv8 与主流目标检测模型的检测结果进行可视化对比,如图8所示。Faster_RCNN 模型的边界框定位较精准,但漏检现象严重,不能识别遮挡严重的籽粒;rtddetr-l 识别精度较好,但存在漏检和重检现象;YOLOv5s 的重检现象较为严重,且存在少数错检现象;YOLOv7 模型的错检现象严重,对遮挡籽粒存在漏检情况;YOLOv8 系列模型检测效果较好,但存在漏检现象,YOLOv8n 模型存在 2 处漏检,YOLOv8s 模型存在 1 处漏检;YOLOv10s 模型的多数籽粒检测置信度均低于改进模型。综合对比,RSSRP_YOLOv8 模型的检测效果最优。

3.2.2 消融试验 以 YOLOv8s 为基线模型,以精确度、召回率、mAP@0.5、mAP@0.5~0.95、浮点运算量、参数量、模型大小、帧率作为评价指标,采用多模块不同组合方式进行消融试验。从表3可知:借鉴 CCFF 模块结构重构模型虽会造成一定的精度损失,但显著降低了模型参数量和大小,提升了模型检测性能,模型大小降低 34.2%,检测帧率提高 15.5%;GSConv 模块的引入实现了模型精度与检测性能的双重提升,各性能指标均有所提升;引入 Dysample 模块对模型检测效率影响较大,检测帧率降低 4.1%,但其在精度提升方面的效果几乎与 GSConv 模块相当。在借鉴 CCFF 模块结构重构模型的基础上,引入 GSConv 和 Dysample 模块,均能弥补模型的精度损失,mAP@0.5 分别增加 0.4%、0.5%。三者组合使用可有效提升模型精度和检测效率,mAP@0.5 增加 0.3%,模型大小降低 42.2%,检测帧率提高 5.9%。

结合消融试验结果,本研究使用 Shapley 值分析法量化分析了各改进模块(CCFF、GSConv、Dysample)对关键性能指标(mAP@0.5、FPS)的独立贡献度,如表4所示。CCFF、GSConv、Dysample 模块的 $\phi_i^{\text{mAP@0.5}}$ 值分别为-0.07、0.20、0.20, ϕ_i^{FPS} 值分别为 5.84、2.48、-4.72, $\phi_i^{\text{综合}}$ 值分别为 0.148 8、0.446 1、0.118 8。

借鉴 CCFF 模块重构模型对模型检测性能提升贡献度最大, ϕ_i^{FPS} 值为 5.84,但对模型精度的贡献值为负,因此需结合精度提升模块消除短板;同理,Dysample 模块对模型精度提升贡献值与 GSConv 模块相当, $\phi_i^{\text{mAP@0.5}}$ 值为 0.20,但对模型检测效率贡献为负,因此需与效率提升模块结合使用;GSConv 模块表现最好,对模型精度和效率均有正向贡献, $\phi_i^{\text{mAP@0.5}}$ 值为 0.20, ϕ_i^{FPS} 值为 2.48。综合对比各模块的加权 Shapley 值,GSConv 模块对模型性能有显著正向贡献, $\phi_i^{\text{综合}}$ 值为 0.446 1,效果最好,CCFF 模块和 Dysample 模块对模型特定性能提升有一定贡献度,但需结合其他模块有效消除其负面影响。




图 8 模型检测效果对比

Fig. 8 Comparison of model detection

表 3 消融试验结果

Table 3 Ablation experiment results

模型 Models	精确度/% Precision	召回率/% Recall	mAP@ 0.5/%	mAP@ 0.5~0.95/%	帧率 FPS/ (f·s ⁻¹)	浮点运算量/GB FLOPs	参数量/MB Parameters	模型大小/MB Model size
YOLOv8s	94.9	93.6	97.9	73.9	61.3	28.6	11.20	22.5
YOLOv8s+A	94.3	93.3	97.6	72.5	70.8	23.2	7.30	14.8
YOLOv8s+B	95.5	94.0	98.1	74.1	65.3	26.4	10.00	20.3
YOLOv8s+C	95.5	93.9	98.0	74.1	58.8	28.7	11.20	22.6
YOLOv8s+A+B	95.4	93.9	98.0	72.8	72.3	21.1	6.35	13.0
YOLOv8s+A+C	95.3	94.3	98.1	72.6	64.4	21.4	6.50	13.3
YOLOv8s+B+C	96.0	94.2	98.2	74.5	63.2	26.4	10.00	20.3
YOLOv8s+A+B+C	95.6	94.2	98.2	73.4	64.9	21.1	6.36	13.0

注:表中 A、B、C 分别表示 CCFF、GSConv、Dysample 模块。A、B、C in the table indicate CCFF,GSConv,Dysample modules.

表 4 改进模块独立贡献度量化分析

Table 4 Quantitative analysis of the independent contribution of improvement modules

模块 i Module i	子集 S Subset S	权重因子 Weighting factor	指标增益 Metric gain		$\phi_i^{\text{mAP@0.5}}$	ϕ_i^{FPS}	$\phi_i^{\text{综合}}$
		$\frac{ S ! (n- S -1)!}{n!}$	$[v(S \cup \{i\}) - v(S)]$				
			$\Delta\text{mAP@0.5}/\%$	$\Delta\text{FPS}/(\text{f}\cdot\text{s}^{-1})$			
A 模块 (CCFF)	ϕ	0.333	-0.3	+9.5	-0.07	5.84	0.148 8
	$\{B\}$	0.167	-0.1	+7.0			
	$\{C\}$	0.167	+0.1	+5.6			
	$\{B,C\}$	0.333	0	+1.7			
B 模块 (GSCov)	ϕ	0.333	+0.2	+4.0	0.20	2.48	0.446 1
	$\{A\}$	0.167	+0.4	+1.5			
	$\{C\}$	0.167	+0.2	+4.4			
	$\{A,C\}$	0.333	+0.1	+0.5			
C 模块 (Dysample)	ϕ	0.333	+0.1	-2.5	0.20	-4.72	0.118 8
	$\{A\}$	0.167	+0.5	-6.4			
	$\{B\}$	0.167	+0.1	-2.1			
	$\{A,B\}$	0.333	+0.2	-7.4			

注:指标增益 $[v(S \cup \{i\}) - v(S)]$ 表示子集 *S* 加入模块 *i* 后的性能指标值减去子集 *S* 的性能指标值。The metric gain $[v(S \cup \{i\}) - v(S)]$ represents the performance metric value after adding module *i* to the subset *S* minus the performance metric value of the subset *S*.

3.3 水稻穗部结实率预测结果分析

3.3.1 主流模型稻穗籽粒及结实率预测性能对比 为衡量模型应用性能,采用模型 RSSRP_YOLOv8 与对比试验中精度较高的 YOLOv5s、YOLOv8s、YOLOv10s 模型对原始 1 100 张稻穗图像的实粒数、空秕粒数及结实率预测结果进行对比分析,各参数预测对比图如图 9 所示。RSSRP_YOLOv8 模型对不同参数(实粒数、空秕粒数、结实率)的拟合效果最好。YOLOv5s 模型拟合效果较差,拟合线位于实际线下方且偏离较大,分析原因在于模型对籽粒的重复识别导致实粒数和空秕粒预测值偏大,且空秕粒预测误差明显高于实




图 9 不同模型参数预测结果对比

Fig. 9 Comparison of prediction results with different model parameters

PFGN、PUGN、PSR 分别表示实粒数预测值、空秕粒数预测值、结实率预测值;TFGN、TUGN、TSR 分别表示实粒数实际值、空秕粒数实际值、结实率实际值。PFGN,PUGN,and PSR represent the predicted number of filled grains,predicted number of unfilled grains,and the predicted setting rate,respectively;TFGN,TUGN,and TSR represent the true number of filled grains,the true number of unfilled grains,and the true setting rate.

粒数预测误差,造成结实率预测值整体偏小,该点可在前文对比试验分析中得到印证;相较于 YOLOv5s 模型,YOLOv8s 和 YOLOv10s 模型对各参数的拟合效果较好,但仍不及改进模型。改进模型 RSSRP_YOLOv8 在实粒、空秕粒、结实率的决定系数(R^2)均达到 0.99 以上;均方根误差(RMSE)分别为 3.05 粒、2.58 粒和 1.24%,较后三者模型中对应参数的最低均方根误差(RMSE)分别降低了 1.87 粒、1.09 粒和 0.74%;平均绝对误差(MAE)为 2.09 粒、1.77 粒和 0.92%,较最低分别降低了 1.13 粒、0.66 粒和 0.56%;平均绝对百分比误差(MAPE)为 2.27%、4.39%和 1.42%,分别降低了 1.12%、1.91%和 0.87%。

3.3.2 稻穗结实率检测结果分析 从表 5 和表 6 可知:由于单株籼稻稻穗籽粒数量较粳稻多,且重叠现象更严重,因此籼稻各参数预测误差值较粳稻大;粳稻各品种不同成熟期稻穗实粒数预测结果均值较原始数据偏少,空秕粒预测结果均值较原始数据偏大,对比稻穗原始图像与检测图像发现,该现象是由于稻穗籽粒未完全成熟前,处于灌浆发育阶段的部分实粒与空秕粒形态高度相似,模型在识别过程中将其识别为空秕粒所致,这也是结实率预测结果均值较原始数据偏少的原因;粳稻与籼稻稻穗总粒数预测结果均值较原始数据偏少,是由于籽粒的重叠遮挡现象使得模型未能识别到部分籽粒。整体而言,本模型对粳稻和籼稻的结实率均值预测误差均在 0.5%以内,模型的泛化性和应用能力较好,可满足多时期、多品种结实率实际预测需求。

表 5 原始数据统计
Table 5 Statistics of original data

组别 Groups	实粒数 Filled grains numbers						空秕粒数 Unfilled grains numbers					
	Max	Max *	Min	Min *	Mean	Mean *	Max	Max *	Min	Min *	Mean	Mean *
A1	126	126	30	30	82.42	81.25	103	108	24	27	67.78	68.22
A2	113	113	24	24	79.05	78.75	82	79	11	11	46.65	46.75
A3	142	142	22	23	83.85	83.39	67	67	9	10	33.80	34.02
B1	141	141	44	43	90.72	90.03	67	69	7	9	33.49	34.17
B2	142	142	51	48	89.94	88.83	58	61	5	5	25.69	25.96
B3	129	128	33	34	79.56	78.88	75	73	9	3	25.88	25.75
C1	187	181	43	42	116.04	114.73	104	103	2	2	36.25	37.09
C2	161	157	50	50	96.09	94.82	63	61	14	13	33.83	34.18
C3	156	154	44	43	99.26	98.38	43	46	2	2	18.51	18.58
D	190	188	26	22	98.34	93.08	163	155	13	13	78.13	74.33
E	188	178	32	28	107.19	101.85	131	122	17	15	73.15	69.87

注:A、B、C 分别为粳稻品种(‘南粳 46’‘金粳 818’‘宁粳 8 号’);D、E 分别为籼稻品种(‘欣两优 2172’‘九优粤禾丝苗’);下标数字 1、2、3 分别代表稻穗不同成熟时期(乳熟期、蜡熟期、完熟期)。Max、Min、Mean 分别表示稻穗参数原始数据的最大值、最小值、均值;Max*、Min*、Mean* 分别表示稻穗参数预测数据的最大值、最小值、均值。下同。A、B、and C represent Japonica rice varieties (‘Nanjing 46’ ‘Jinjing 818’ ‘Ningjing No. 8’);D and E represent Indica rice varieties (‘Xinliangyou 2172’ ‘Jiuyouyuehesimiao’);The subscript numbers 1,2,and 3 represent different maturity stages of the rice panicle (milky stage, wax maturity stage, and full maturity stage). Max, Min, Mean represent the maximum value, minimum value, and mean value of the original rice panicle parameter data; Max*, Min*, Mean* represent the maximum value, minimum value, and mean value of the predicted rice panicle parameter data. The same as follows.

表 6 模型预测结果统计
Table 6 Statistics of model prediction results

组别 Groups	总粒数 Total grains numbers						结实率/% Seed-setting rate					
	Max	Max *	Min	Min *	Mean	Mean *	Max	Max *	Min	Min *	Mean	Mean *
A1	201	195	80	79	150.20	149.47	79.66	77.31	30.36	29.77	54.79	54.25
A2	175	173	35	35	125.70	125.50	86.92	86.92	50.63	50.31	63.30	63.18
A3	170	171	36	36	117.65	117.41	89.09	89.09	51.35	52.21	71.45	71.22
B1	175	177	79	79	124.21	124.20	92.45	92.16	46.67	45.76	73.43	72.88
B2	165	164	64	64	115.63	114.79	94.17	95.08	55.34	52.71	77.92	77.47
B3	165	164	54	54	105.44	104.63	96.52	96.49	47.55	48.23	75.97	75.86
C1	242	237	85	86	152.29	151.82	98.32	98.33	50.59	48.84	77.10	76.53
C2	185	183	78	79	129.92	129.00	89.44	90.58	51.33	51.79	73.61	73.12
C3	165	166	71	71	117.77	116.96	97.56	97.56	55.70	53.75	84.03	83.83
D	311	305	81	75	176.47	167.41	87.25	86.73	28.89	26.72	55.52	55.31
E	262	252	91	84	180.34	171.72	89.51	90.06	31.25	30.76	59.27	59.14

进一步对模型预测结果进行误差分析(表 7)可知:实粒预测方面,粳稻和籼稻的平均绝对误差分别在 2 粒和 6 粒以内,平均绝对百分比误差分别在 2.50%和 6.00%之内;空秕粒预测方面,除‘南粳 46’品种乳熟期平均绝对误差超过 2 粒外,其他粳稻均在 2 粒以内,籼稻品种在 4 粒以内,平均绝对百分比误差均保

持在 5.00%左右;结实率预测方面,各品种各成熟期平均绝对误差均在 1.00%左右,平均绝对百分比误差保持在 2.00%左右,均方根误差保持在 1.50%左右。空秕粒的识别准确率随着稻穗成熟程度增加而提高,结实率结果与之类似,分析原因在于随着稻穗籽粒的逐渐成熟,实粒与空秕粒之间的特征差异逐渐增大,使得模型更易区分二者,这与表 5 和表 6 的结果分析一致,证实了籽粒特征相似性对模型识别精度的影响。

表 7 模型预测结果误差分析
Table 7 Errors analysis of model prediction results

组别 Groups	实粒 Filled grains			空秕粒 Unfilled grains			结实率 Seed-setting rate		
	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE
A1	1.87	2.46	2.42	2.10	3.11	2.95	1.19	2.38	1.56
A2	1.00	1.23	1.56	1.46	3.24	1.86	0.93	1.48	1.19
A3	1.12	1.38	1.59	1.44	4.48	2.00	1.08	1.55	1.39
B1	1.17	1.32	1.73	1.26	4.16	1.85	0.93	1.30	1.30
B2	1.37	1.55	1.98	1.03	4.42	1.47	0.90	1.21	1.31
B3	1.08	1.40	1.76	0.95	4.38	1.31	0.77	1.03	1.03
C1	1.87	1.61	2.45	1.70	5.47	2.54	0.97	1.33	1.35
C2	1.67	1.80	2.20	1.29	4.16	1.71	0.95	1.31	1.24
C3	1.24	1.25	1.79	0.79	4.61	1.31	0.65	0.80	0.98
D	5.26	5.80	5.66	3.94	5.16	4.55	0.78	1.52	1.03
E	5.34	5.11	5.93	3.52	5.09	4.27	0.96	1.72	1.19

3.3.3 模型误判籽粒样本特征及类型分布 基于前文模型性能评价试验与 3.3.2 节结实率预测结果分析,结合 RSSRP_YOLOv8 模型检测的 1 100 张稻穗效果图,对模型误判籽粒样本特征及其类型分布进行分析,如图 10 所示。误判籽粒样本类型主要有 2 种:1)乳熟期阶段,颜色相近、形态相似且遮挡的稻穗实粒。稻穗成熟初期,部分实粒未完全灌浆,与空秕粒颜色相近、形态相似,同时还存在遮挡现象,使得模型在识别过程中将该部分实粒识别为空秕粒,造成结实率检测结果整体偏小。2)着粒密度较大枝梗区域的空秕粒。虽然在图像采集前已经对稻穗的一次枝梗和部分重叠二次枝梗进行分离,但无法对枝梗上重叠粘连严重的籽粒进行分离。该类籽粒多为穗上发育不足的空秕粒,其在生长过程中与周围籽粒粘连在一起,形成区域性籽粒堆积,导致模型在识别过程中对该类籽粒的特征信息获取不够,判定条件不足而造成模型漏判。3)还有部分误判籽粒产生原因在于模型性能提升的技术瓶颈,当前模型的 mAP@0.5 已达到 98.2%,但仍存在一定的检测误差。目标检测是涉及多环节的复杂任务,其精度受多重因素制约,且在实际场景中存在无法完全消除的不确定性,因此,模型在籽粒识别过程中,依旧会存在一定的识别偏差,导致误判籽粒样本。




图 10 误判籽粒样本类型
Fig. 10 Misjudgment of grain sample type

4 结论

本研究构建了一种离体稻穗穗部结实率检测模型 RSSRP_YOLOv8,基于图像层面实现了离体稻穗结实率无损检测,为育种研究中离体稻穗样本结实率性状获取提供了技术支撑。主要结论如下:

1) 检测方法优势明显。与脱粒检测相比,本方法省去了脱粒环节,降低了脱粒过程中的籽粒损耗,保证稻穗结构完整性,提高了检测精度和效率;与穗上检测相比,本方法平均实粒数测量误差为 2.27%,提升 0.57%;本方法更具实用性,无需进行图像分割,可一次实现结实率检测,模型在测试集上的 mAP@0.5 为 98.2%,单张检测速率达到了 15.4 ms,可更快速、准确地检测离体稻穗结实率。

2) 模型性能表现优异。本模型在测试集上的平均精度均值 mAP@0.5 达到了 98.2%,相比于主流的 Faster_RCNN、rt-detr-l、YOLOv5s、YOLOv7、YOLOv8n、YOLOv10s 等模型分别提升了 34.8%、19.1%、2.4%、6.1%、4.1%、0.7%,具备一定优势;检测性能方面,模型浮点计算量和模型大小分别为 21.1 GB 和 13.0 MB,相比于原始模型分别降低 26.2% 和 42.2%,增强了模型可扩展性和部署应用可能性,检测帧率达 $64.9 \text{ f}\cdot\text{s}^{-1}$,满足稻穗检测需求。

3) 检测结果稳定可靠,通过对 1 100 张原始稻穗图像进行结实率预测,改进后的 RSSRP_YOLOv8 模型在实粒、空秕粒、结实率预测中,决定系数(R^2)均超过 0.99,平均绝对误差(MAE)为 2.09 粒、1.77 粒和 0.92%,预测精度达到 99% 以上,平均绝对百分比误差(MAPE)为 2.27%、4.39% 和 1.42%,具备较强的应用潜力和可靠性。

综上,本模型在保证检测精度的同时,兼顾了实时性与实用性,具有较高的应用价值。由于稻穗籽粒在自然状态下重叠遮挡过于严重,现有检测方法需在图像采集时人工分离遮挡枝梗,在一定程度上增加了工作量。未来可通过开发自动化枝梗分离装置实现枝梗自动分离,同时本研究已进行模型轻量化设计,后续可探索将模型部署至移动端,或开发基于 PyQt 或 Streamlit 的本地化软件,与分离装置进行集成,搭建离体稻穗结实率一体化检测平台,在工程实用性方面构建闭环验证体系。此外,本研究对籼稻仅采集了 2 个品种完熟期稻穗图像进行结实率检测,后续可补充多时期图像进一步提高模型泛化性。

参考文献 References:

- [1] 王勇,陶兆胜,石鑫宇,等. 基于改进 YOLOv5s 的不同成熟度苹果目标检测方法[J]. 南京农业大学学报,2024,47(3): 602-611.
Wang Y, Tao Z S, Shi X Y, et al. Apple target detection method with different ripeness based on improved YOLOv5s[J]. Journal of Nanjing Agricultural University, 2024, 47(3): 602-611 (in Chinese with English abstract).
- [2] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. June 23-28, 2014, Columbus, OH, USA. IEEE, 2014: 580-587.
- [3] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 779-788.
- [4] 岳凯,张鹏超,王磊,等. 基于改进 YOLOv8n 的复杂环境下柑橘识别[J]. 农业工程学报,2024,40(8): 152-158.
Yue K, Zhang P C, Wang L, et al. Recognizing *Citrus* in complex environment using improved YOLOv8n[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(8): 152-158 (in Chinese with English abstract).
- [5] 曹丽英,钟钊澳,赵浩宇,等. 一种基于无人机 RGB 图像的玉米雄穗检测方法[J]. 沈阳农业大学学报,2025,56(6): 20-30.
Cao L Y, Zhong G A, Zhao H Y, et al. A detecting method for maize tassels based on UAV RGB images[J]. Journal of Shenyang Agricultural University, 2025, 56(6): 20-30 (in Chinese with English abstract).
- [6] 吴利刚,陈乐,刘泽鹏,等. 基于 YOLOv8-ABW 的黄花成熟度检测方法[J]. 农业工程学报,2024,40(13): 262-272.
Wu L G, Chen L, Liu Z P, et al. YOLOv8-ABW based method for detecting *Hemerocallis citrina* Baroni maturity[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(13): 262-272 (in Chinese with English abstract).
- [7] 李瑞鑫,曹悦,司秀丽,等. 基于改进 YOLOv8n 的樱桃成熟度检测研究[J]. 智能化农业装备学报(中英文),2025,6(4): 40-49.
Li R X, Cao Y, Si X L, et al. Research on cherry ripeness detection based on improved YOLOv8n[J]. Journal of Intelligent Agricultural Mechanization, 2025, 6(4): 40-49 (in Chinese with English abstract).
- [8] Lu Y, Yu J H, Zhu X F, et al. YOLOv8-Rice: a rice leaf disease detection model based on YOLOv8[J]. Paddy and Water Environment, 2024, 22(4): 695-710.
- [9] 靳新宇,于复兴,索依娜,等. 基于改进 YOLOv8 的水稻病害检测算法[J]. 江苏农业学报,2025,41(3): 537-548.
Jin X Y, Yu F X, Suo Y N, et al. Rice disease detection algorithm based on improved YOLOv8[J]. Jiangsu Journal of Agricultural Sciences, 2025, 41(3): 537-548 (in Chinese with English abstract).
- [10] Duan L F, Yang W N, Bi K, et al. Fast discrimination and counting of filled/unfilled rice spikelets based on bi-modal imaging[J]. Computers

- and Electronics in Agriculture, 2011, 75(1): 196–203.
- [11] Liu T, Ji C X, Wu W, et al. Measurement of rice filled grain percentage based on grain shadow features[J]. Agronomy Journal, 2016, 108(3): 1070–1078.
- [12] Feng X, Wang Z Q, Zeng Z W, et al. Size measurement and filled/unfilled detection of rice grains using backlight image processing[J]. Frontiers in Plant Science, 2023, 14: 1213486.
- [13] Zhou J, Lu X Y, Yang R, et al. Developing thermal infrared de-ghost and multi-level nested conglutinated segmentation algorithm for detection of rice seed setting rate[J]. Computers and Electronics in Agriculture, 2023, 207: 107725.
- [14] Kong H H, Chen P. Mask R-CNN-based feature extraction and three-dimensional recognition of rice panicle CT images[J]. Plant Direct, 2021, 5(5): e00323.
- [15] Guo Y X, Li S, Zhang Z G, et al. Automatic and accurate calculation of rice seed setting rate based on image segmentation and deep learning[J]. Frontiers in Plant Science, 2021, 12: 770916.
- [16] Sun J, Ren Z W, Cui J L, et al. A high-throughput method for accurate extraction of intact rice panicle traits[J]. Plant Phenomics, 2024, 6: 213.
- [17] 张续博, 张家瑜, 贲宗友, 等. 基于 YOLOv5-RF 的糙米内部裂纹识别方法研究[J]. 南京农业大学学报, 2024, 47(4): 792–802.
- Zhang X B, Zhang J Y, Ben Z Y, et al. Research on internal crack recognition method of brown rice based on YOLOv5-RF[J]. Journal of Nanjing Agricultural University, 2024, 47(4): 792–802 (in Chinese with English abstract).
- [18] Zhao Y A, Lv W Y, Xu S L, et al. DETRs beat YOLOs on real-time object detection[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 16–22, 2024, Seattle, WA, USA. IEEE, 2024: 16965–16974.
- [19] Li H L, Li J, Wei H B, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures[EB/OL]. 2022; arXiv: 2206.02424. <https://arxiv.org/abs/2206.02424>.
- [20] Liu W Z, Lu H, Fu H T, et al. Learning to upsample by learning to sample[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). October 1–6, 2023, Paris, France. IEEE, 2023: 6004–6014.
- [21] Rozemberczki B, Watson L, Bayer P, et al. The shapley value in machine learning[C]//Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence. July 23–29, 2022. Vienna, Austria. International Joint Conferences on Artificial Intelligence Organization, 2022: 5572–5579.
- [22] Wang A, Chen H, Liu L H, et al. YOLOv10: real-time end-to-end object detection[EB/OL]. 2024; arXiv: 2405.14458. <https://arxiv.org/abs/2405.14458>.

责任编辑: 刘怡辰